



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 4 No. 3 (2025) pp: 2538-2544

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Analisis Prediksi Harga Sewa Ruko Menggunakan Pendekatan *Machine Learning*

Yunadi Fitra Munawar¹, Andria Arisal²

¹Program Studi Bisnis Digital, Fakultas Ekonomi dan Bisnis, Universitas Padjadjaran

²Departemen Manajemen dan Bisnis, Fakultas Ekonomi dan Bisnis, Universitas Padjadjaran

yunadi21001@mail.unpad.ac.id^{1*}, andria.arisal@brin.go.id²

Abstrak

Penelitian ini mengembangkan sistem prediksi harga sewa ruko menggunakan pendekatan *machine learning* di tiga kota besar di Indonesia: Jakarta, Semarang, dan Surabaya. Ruko merupakan komponen penting dalam pasar properti komersial di Indonesia. Penentuan harga sewa yang akurat sangat dibutuhkan oleh pemilik properti, investor, maupun pemerintah daerah. Penelitian ini menggunakan tiga algoritma *machine learning*: *Random Forest*, *Support Vector Regression (SVR)*, dan *XGBoost*. Data diperoleh dari hasil *web scraping* situs properti online dan diperkaya dengan variabel tambahan seperti kepadatan penduduk. Evaluasi dilakukan menggunakan *MAE*, *MAPE*, *RMSE*, dan *R² Score*. Hasilnya, *SVR* menunjukkan kinerja terbaik di Semarang dan Surabaya, sementara *XGBoost* unggul di Jakarta. Agar dapat digunakan secara luas, model terbaik diintegrasikan ke dalam aplikasi web sederhana berbasis *Streamlit*. Pengguna cukup memasukkan detail properti, dan sistem akan memberikan estimasi harga sewa secara langsung. Aplikasi ini memberikan kemudahan dalam penilaian harga sewa yang cepat dan objektif, serta mendukung pengambilan keputusan berbasis data di sektor properti Indonesia.

Kata Kunci: Harga Sewa Ruko, Prediksi Properti, *Machine Learning*, *Random Forest*, *SVR*, *XGBoost*.

1. Latar Belakang

Kamus Besar Bahasa Indonesia mendefinisikan frasa properti sebagai aset yang terdiri dari tanah dan bangunan beserta infrastruktur pendukungnya, dan salah satu jenis yang umum digunakan di sektor komersial adalah rumah toko (ruko). Ruko berfungsi ganda sebagai tempat tinggal dan lokasi usaha, serta digunakan oleh berbagai skala bisnis. Dalam praktiknya, penentuan harga sewa ruko sering kali menjadi tantangan karena ketidaktepatan harga dapat berdampak pada efisiensi operasional baik dari sisi pemilik maupun penyewa. Metode tradisional seperti pendekatan komparatif dan pendekatan pendapatan memang telah lama digunakan, namun belum mampu menangani kompleksitas variabel yang memengaruhi harga secara efektif, sehingga prosesnya menjadi mahal dan kurang efisien (Olanrewaju et al., 2018). Selain itu, sistem penentuan harga juga bervariasi antar negara, dipengaruhi oleh perbedaan hukum dan konteks lokal masing-masing (Pagourtzi et al., 2003).

Seiring dengan kemajuan teknologi, *machine learning* mulai dimanfaatkan dalam prediksi harga properti karena kemampuannya dalam menangkap pola kompleks dan menghasilkan estimasi yang akurat (Ho et al., 2021). Beberapa studi terdahulu menunjukkan efektivitas algoritma seperti *Random Forest* dalam menangkap dinamika harga (Ja'afar et al., 2021; Mohd et al., 2019) *Gradient Boosting* dalam meningkatkan akurasi model melalui koreksi bertahap, dan *Support Vector Regression (SVR)* yang unggul dalam mengelola hubungan non-linear (Ho et al., 2021). Meskipun demikian, penelitian yang secara spesifik mengaplikasikan *machine learning* untuk prediksi harga sewa ruko masih sangat terbatas, membuka ruang bagi kontribusi akademik dan praktis yang baru.

Properti komersial adalah bangunan yang digunakan untuk kegiatan bisnis seperti kantor, hotel, dan pusat perbelanjaan (Geltner & Neufville, 2017). Salah satu jenisnya adalah ruko (rumah toko), yaitu bangunan yang menggabungkan tempat tinggal dan tempat usaha. Ruko populer di Indonesia karena letaknya strategis dan cocok untuk pelaku UMKM (Prigita & Lantara, 2017). Faktor yang memengaruhi harga sewa ruko antara lain lokasi (kecamatan), ukuran bangunan, jumlah lantai, fasilitas parkir, serta kepadatan penduduk di sekitar (Prigita & Lantara, 2017; Rahmawati & Soeratno, 2012).

Secara tradisional, harga sewa ditentukan dengan membandingkan properti serupa, menghitung biaya bangunan, atau memperkirakan pendapatan yang dihasilkan (Olanrewaju et al., 2018; Pagourtzi et al., 2003). Namun, metode ini sering kurang akurat untuk mengikuti perubahan pasar (Ho et al., 2021). Saat ini, teknologi *machine learning*

mulai digunakan karena mampu menganalisis banyak faktor sekaligus untuk memprediksi harga secara lebih tepat dan efisien (Chen & Guestrin, 2016; Ja'afar et al., 2021; Ma et al., 2018).

Berdasarkan kajian literatur dari berbagai penelitian terdahulu yang dirangkum oleh Ja'afar et al. (2021), dapat disimpulkan bahwa algoritma *machine learning* yang paling sering digunakan untuk memprediksi harga properti adalah Linear Regression (12 studi) dan *Random Forest* (11 studi), diikuti oleh algoritma lain seperti *Support Vector Machine*, *Decision Tree*, dan *Gradient Boosting*. Dari segi akurasi dan performa, *Random Forest* menjadi algoritma yang paling unggul dan sering menghasilkan prediksi terbaik (8 studi), karena kemampuannya menangani data dengan variabel kompleks dan memberikan hasil yang akurat. Penelitian-penelitian seperti oleh Adetunji et al. (2021), Ma et al. (2018), dan Shokoohyar et al. (2020) menegaskan bahwa *Random Forest* sangat efektif dalam memprediksi harga sewa properti, menjadikannya sebagai pilihan utama dalam pengembangan model prediksi harga sewa ruko pada penelitian ini.

Penelitian ini bertujuan untuk mengeksplorasi variabel-variabel penentu harga sewa ruko dan membangun model prediktif menggunakan algoritma *Support Vector Machine* (SVM), *Gradient Boosting*, dan *Random Forest*. Ketiga algoritma ini dipilih berdasarkan keunggulannya dalam studi sebelumnya terkait estimasi nilai properti. Proses penelitian mencakup pembuatan dataset dari wilayah DKI Jakarta, Semarang, dan Surabaya melalui web scraping dari berbagai platform properti daring, pelatihan dan evaluasi model berdasarkan akurasi prediksi, serta integrasi model ke dalam sistem berbasis web. Aplikasi ini dirancang untuk memberikan estimasi harga secara instan, menggantikan proses manual yang umumnya membutuhkan waktu 10–15 menit hanya untuk satu unit ruko. Pendekatan ini diharapkan mampu meningkatkan efisiensi, konsistensi, dan objektivitas dalam proses penentuan harga, serta mendukung terciptanya pasar properti yang lebih transparan.

Lebih jauh, penelitian ini juga menjawab tiga pertanyaan utama: (1) Apakah *machine learning* dapat digunakan untuk memperkirakan harga sewa ruko? (2) Faktor-faktor apa saja yang memengaruhi harga sewa ruko? dan (3) Algoritma *machine learning* mana yang paling efektif dalam memberikan prediksi harga sewa ruko yang akurat? Temuan dari penelitian ini diharapkan dapat menjadi dasar pengembangan sistem pendukung keputusan harga sewa ruko yang adaptif dan aplikatif bagi pemilik, penyewa, investor, hingga pengambil kebijakan.

Penelitian ini menggunakan tiga algoritma *machine learning*, yaitu *Support Vector Regression* (SVR), *Random Forest*, dan XGBoost. Evaluasi dilakukan berdasarkan metrik performa prediktif seperti *Mean Absolute Percentage Error* (MAPE) dan R-squared (R^2). Selain itu, penelitian ini juga mengamati pengaruh fitur-fitur properti terhadap nilai harga sewa serta perbedaan performa model antar kota.

Adapun hipotesis yang diajukan dalam penelitian ini adalah sebagai berikut:

H₁: Algoritma XGBoost memberikan hasil prediksi harga sewa ruko yang lebih akurat dibandingkan algoritma SVR dan *Random Forest*, berdasarkan nilai MAPE dan R^2 .

H₂: Seluruh model *machine learning* yang digunakan (SVR, *Random Forest*, dan XGBoost) mampu menghasilkan nilai MAPE < 20

H₃: Kota Jakarta memiliki performa model prediksi harga sewa yang lebih baik dibandingkan Semarang dan Surabaya, dilihat dari nilai akurasi model.

H₄: Luas bangunan, jumlah lantai, dan kepadatan penduduk merupakan fitur yang paling berpengaruh terhadap harga sewa ruko dibandingkan fitur lainnya.

Hipotesis-hipotesis tersebut akan diuji melalui eksperimen pemodelan prediktif, evaluasi kinerja model, dan analisis data secara kuantitatif. Hasil pengujian hipotesis ini akan menjadi dasar dalam menjawab rumusan masalah dan menarik kesimpulan dari penelitian yang dilakukan.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental untuk mengembangkan model prediksi harga sewa ruko berbasis *machine learning*. Metode kuantitatif dipilih karena fokus pada analisis data numerik guna menjawab pertanyaan penelitian secara objektif (Kasiram, 2010). Proses dilakukan melalui beberapa tahap, yaitu: pengumpulan data dari situs properti, pembersihan dan transformasi data, pelatihan model dengan algoritma *machine learning* (*Random Forest*, XGBoost, dan SVR), evaluasi model, dan analisis hasil. Semua analisis dilakukan menggunakan Python dan hasil akhir model akan diaplikasikan dalam bentuk prototipe web.

Pengumpulan dan pengolahan data dilakukan dengan teknik web scraping dari dua situs properti daring yaitu Rumah123 dan Lamudi, yang menghasilkan total 6.430 data ruko. Variabel yang dikumpulkan meliputi: harga sewa, luas bangunan, luas tanah, jumlah lantai, lokasi (kecamatan), dan fasilitas. Data pelengkap seperti kepadatan penduduk diperoleh dari data sekunder BPS. Setelah itu, dilakukan data cleaning seperti menghapus data kosong, mengonversi data string ke numerik, menghapus *outlier* dan duplikasi. Kemudian, dilakukan transformasi data

seperti one-hot *encoding* pada lokasi, serta penghitungan jumlah fasilitas menjadi nilai numerik agar model dapat memproses data dengan optimal.

Pemilihan algoritma mencakup *Random Forest* (Breiman, 2001), *XGBoost* (Chen & Guestrin, 2016), dan *SVR* (Cortes et al., 1995), karena dikenal efektif menangani data non-linear, kompleks, serta tahan terhadap *overfitting*. Model dilatih menggunakan metode *k-fold cross-validation* (Kohavi & Elu, 1993) dan dilakukan hyperparameter tuning untuk mendapatkan hasil terbaik. Model dievaluasi menggunakan beberapa metrik yaitu MAPE (Armstrong & Collopy, 1992), MAE (Willmott & Matsuura, 2005), Relative RMSE (Chai & Draxler, 2014), dan R^2 (James, 2013). Hasil prediksi dari tiap algoritma dibandingkan, disertai analisis terhadap variabel yang paling berpengaruh dan kesesuaian hasil dengan harga pasar aktual. Setelah model dievaluasi, hasil prediksi dari ketiga algoritma akan dibandingkan untuk menentukan algoritma yang paling akurat dalam memprediksi harga sewa ruko. Analisis ini meliputi interpretasi terhadap fitur-fitur yang paling berpengaruh pada model serta perbandingan hasil prediksi dengan harga pasar aktual. Penelitian ini juga mengkaji tingkat sensitivitas model terhadap variasi dalam variabel utama seperti luas tanah, fasilitas, dan lokasi.

3. Hasil dan Diskusi



Gambar 1. Rata Rata Harga per Kota



Gambar 2. Rata Rata Luas Tanah dan Luas Bangunan



Gambar 3. Rata Rata Harga Sewa Kota Jakarta



Gambar 4. Rata Rata Harga Sewa Kota Semarang



Gambar 5. Rata Rata Harga Sewa Kota Jaka

Hasil analisis deskriptif terhadap data sewa ruko di Jakarta, Semarang, dan Surabaya menunjukkan bahwa Jakarta memiliki rata-rata harga sewa tertinggi, diikuti Semarang dan Surabaya, dengan Jakarta juga memiliki bangunan terbesar meski luas tanahnya lebih kecil mengindikasikan pemanfaatan ruang vertikal. Distribusi data menunjukkan dominasi ruko di Jakarta, yang juga menjadi pusat aktivitas ekonomi. Analisis kecamatan menunjukkan konsentrasi harga sewa tinggi di wilayah strategis, seperti Jatinegara di Jakarta, Candisari di Semarang, dan Dukuh Pakis di Surabaya. Terkait ukuran fisik, ruko di Jakarta dan Surabaya cenderung lebih besar dari Semarang, namun pemanfaatan ruang berbeda-beda antar kota. Dari sisi segmentasi harga, Jakarta memiliki distribusi yang merata di semua kelas, sedangkan Semarang dan Surabaya didominasi oleh kelas bawah dan menengah bawah, mencerminkan perbedaan daya beli dan karakter pasar di masing-masing kota.

Dalam penelitian ini, tiga algoritma *machine learning* yakni *Random Forest*, *Support Vector Regression (SVR)*, dan *XGBoost* digunakan untuk memprediksi harga sewa ruko di Jakarta, Semarang, dan Surabaya. *Pipeline* pemodelan mencakup preprocessing data, yaitu standarisasi fitur numerik dengan *StandardScaler* dan *encoding* fitur kategorikal dengan *OneHotEncoder*. Seluruh model dioptimalkan menggunakan *RandomizedSearchCV*,

DOI: <https://doi.org/10.31004/riggs.v4i3.2184>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

yaitu teknik pencarian acak dalam ruang parameter untuk menemukan kombinasi hyperparameter terbaik berdasarkan performa validasi silang.

Untuk *Random Forest*, parameter yang disesuaikan meliputi *n_estimators* (jumlah pohon dalam hutan), *max_depth* (kedalaman maksimum tiap pohon), dan *min_samples_split* (jumlah minimal sampel untuk membagi node). Model ini unggul dalam menangani data dengan banyak variabel dan hubungan non-linier, namun cenderung overfit jika tidak diatur dengan baik. Pada SVR, tuning dilakukan terhadap parameter C (regularisasi), epsilon (batas toleransi kesalahan), dan kernel (fungsi inti, seperti radial basis function/RBF). SVR menunjukkan performa terbaik secara keseluruhan, terutama di kota dengan hubungan fitur yang kompleks dan non-linier seperti Surabaya dan Semarang.

Sementara itu, XGBoost disempurnakan dengan pengaturan parameter seperti *n_estimators*, *learning_rate*, *max_depth*, dan *subsample*. Model ini dikenal sangat efisien dan cepat dalam proses training, serta memiliki mekanisme regularisasi bawaan (*lambda*, *alpha*) yang membantu mencegah *overfitting*. Di Jakarta, XGBoost memberikan hasil terbaik, mencerminkan kemampuannya menangkap kompleksitas pasar properti yang dinamis. Implementasi ketiga model ini berhasil memangkas waktu estimasi harga sewa dari 15 menit menjadi hanya beberapa detik, menjadikannya alat yang efektif bagi berbagai pihak untuk pengambilan keputusan cepat dan berbasis data.

Tabel 1. Hasil Evaluasi Model per Kota

Kota	Model	MAE (Rp)	MAPE (%)	RMSE Relatif (%)	R ² Score
Jakarta	SVR	16,764,299	8.84	13.14	0.6024
	Random Forest	18,263,448	9.66	13.62	0.5727
	XGBoost	16,448,410	8.78	12.98	0.6123
Surabaya	SVR	8,514,112	8.77	14.50	0.6700
	Random Forest	13,795,583	11.90	15.75	0.6106
	XGBoost	10,931,724	10.36	14.76	0.6581
Semarang	SVR	13,699,428	12.09	12.75	0.7438
	Random Forest	15,824,024	13.83	15.84	0.6041
	XGBoost	16,966,324	14.19	16.41	0.5753

Hasil evaluasi menunjukkan bahwa *Support Vector Regression* (SVR) merupakan model paling akurat untuk memprediksi harga sewa ruko, khususnya di Surabaya dan Semarang, dengan MAPE di bawah 10% dan R² di atas 0.67. Di Jakarta, meskipun selisihnya kecil, XGBoost sedikit unggul dari SVR dengan R² tertinggi sebesar 0.6123 dan MAPE 8.78%, menunjukkan kinerjanya yang efektif di pasar properti yang dinamis. *Random Forest* memiliki performa yang cukup stabil namun konsisten berada di bawah dua model lainnya. SVR terbukti paling akurat dalam menangani data dengan hubungan non-linier dan variabel yang kompleks, diikuti oleh XGBoost yang unggul dalam kecepatan prediksi di pasar dinamis seperti Jakarta.

Implementasi model *machine learning* seperti SVR, *Random Forest*, dan XGBoost mampu mempercepat estimasi harga sewa ruko dari 15 menit menjadi hanya beberapa detik dengan tingkat akurasi tinggi. Hal ini memberikan manfaat besar bagi agen properti, pemilik ruko, dan investor dalam menentukan harga secara tepat dan efisien. Selain itu, pemerintah daerah dapat memanfaatkan model ini untuk perencanaan tata kota dan pengembangan kawasan komersial berbasis data, sehingga mendukung pengambilan keputusan yang lebih strategis dan objektif.

Implementasi teknologi prediktif dalam sektor properti telah menjadi pendekatan strategis yang semakin relevan di era digital. Salah satu penerapan konkret dari inovasi ini adalah pengembangan sistem prediksi harga sewa ruko berbasis web, yang membawa dampak signifikan bagi berbagai pemangku kepentingan. Sistem ini tidak hanya mempercepat proses estimasi harga yang sebelumnya dilakukan secara manual dalam waktu ±15 menit menjadi hanya beberapa detik, tetapi juga meningkatkan akurasi dengan nilai *Mean Absolute Percentage Error* (MAPE) di bawah 10%, yang mencerminkan kedekatan hasil prediksi dengan harga aktual pasar. Selain itu, kemudahan akses menjadi nilai tambah tersendiri, karena pengguna dari latar belakang non-teknis sekalipun dapat mengoperasikan aplikasi ini tanpa perlu memahami dasar-dasar *machine learning*. Dari sisi pengembangan, sistem ini juga dirancang fleksibel dan skalabel, memungkinkan ekspansi ke kota lain, penambahan variabel, atau integrasi dengan database real-time di masa mendatang. Manfaat ini memperkuat fungsi sistem sebagai alat bantu pengambilan keputusan yang berbasis data, tidak hanya bagi pemilik ruko dan agen properti, tetapi juga investor dan pemerintah daerah. Dengan demikian, implementasi sistem ini membuka ruang diskusi lebih lanjut mengenai optimalisasi pemanfaatan teknologi prediktif dalam mendukung transparansi harga, efisiensi pasar, serta perumusan kebijakan tata ruang berbasis data di sektor properti komersial.

Berdasarkan hasil temuan dan keterbatasan penelitian ini, terdapat beberapa rekomendasi untuk pengembangan ke depan. Penelitian selanjutnya disarankan untuk memperluas cakupan wilayah studi ke kota-kota lain di Indonesia, termasuk kota besar dan berkembang, guna meningkatkan generalisasi model dan representasi kondisi pasar properti secara nasional. Selain itu, penambahan variabel eksternal seperti kedekatan dengan pusat perbelanjaan, akses transportasi publik, indeks pembangunan manusia, dan indikator ekonomi makro lokal diperlukan untuk memperkaya konteks analisis dan meningkatkan akurasi prediksi. Pengembangan model prediktif berbasis time-series seperti ARIMA atau LSTM juga direkomendasikan untuk menangkap dinamika harga secara temporal, mengingat model saat ini masih bersifat statis. Di sisi lain, eksplorasi terhadap algoritma lanjutan seperti *Deep Neural Networks* (DNN), *Convolutional Neural Networks* (CNN), atau model *hybrid* dapat menjadi alternatif untuk meningkatkan performa sistem. Dari sisi implementasi, pengembangan sistem web dapat ditingkatkan melalui integrasi API dari platform properti *real-time* serta pemanfaatan data spasial berbasis Sistem Informasi Geografis (SIG/GIS), sehingga aplikasi lebih otomatis dan interaktif. Terakhir, pemanfaatan teknologi ini oleh pemerintah daerah dan pengembang properti diharapkan dapat mendukung perumusan kebijakan tata ruang dan strategi investasi yang lebih berbasis data, sekaligus mendorong adopsi kecerdasan buatan secara luas dan inklusif dalam sektor properti komersial Indonesia.

4. Kesimpulan

Penelitian ini bertujuan untuk mengembangkan model prediksi harga sewa ruko di tiga kota besar Indonesia: Jakarta, Semarang, dan Surabaya, menggunakan pendekatan *machine learning* dengan memanfaatkan tiga algoritma utama, yaitu *Random Forest*, *Support Vector Regression* (SVR), dan *Extreme Gradient Boosting* (XGBoost). Berdasarkan hasil analisis deskriptif dan evaluasi kinerja model, dapat disimpulkan bahwa *machine learning* merupakan pendekatan yang efektif dan efisien dalam memprediksi harga sewa ruko. Model yang dibangun mampu memberikan hasil prediksi dengan tingkat akurasi yang tinggi, ditunjukkan oleh nilai *Mean Absolute Percentage Error* (MAPE) di bawah 15% dan koefisien determinasi (R^2) yang mencapai di atas 0.60 pada sebagian besar kota. SVR menunjukkan performa terbaik di kota Semarang dengan R^2 sebesar 0.7438 dan MAPE sebesar 12.09%, sedangkan XGBoost memberikan hasil terbaik di Jakarta dengan MAPE terendah sebesar 8.78% dan R^2 sebesar 0.6123. Selain itu, hasil analisis menunjukkan bahwa Jakarta memiliki rata-rata harga sewa ruko tertinggi, diikuti oleh Semarang dan Surabaya. Perbedaan harga sewa antar kota ini mencerminkan variasi dalam struktur ekonomi, permintaan pasar, serta tingkat kematangan infrastruktur di masing-masing wilayah. Faktor-faktor utama yang memengaruhi harga sewa ruko adalah luas bangunan, lokasi (kecamatan), kepadatan penduduk, jumlah lantai, dan jumlah fasilitas yang tersedia. Jakarta cenderung menunjukkan pola pembangunan vertikal dengan luas bangunan yang lebih besar meskipun lahan terbatas, sedangkan Surabaya dan Semarang lebih didominasi oleh properti di kelas harga bawah hingga menengah. Model prediksi yang dikembangkan telah berhasil diimplementasikan ke dalam sebuah aplikasi berbasis web menggunakan *framework* Streamlit. Aplikasi ini memungkinkan pengguna, baik dari kalangan teknis maupun non-teknis, untuk memprediksi harga sewa ruko secara instan dengan memasukkan beberapa informasi dasar terkait properti. Dengan prediksi yang dihasilkan dalam hitungan detik, sistem ini tidak hanya meningkatkan efisiensi waktu, tetapi juga memberikan hasil yang akurat dan dapat diandalkan dalam mendukung pengambilan keputusan oleh pemilik ruko, agen properti, investor, dan pemerintah daerah. Oleh karena itu, penelitian ini membuktikan bahwa pendekatan *machine learning* dapat memberikan kontribusi nyata dalam mendukung digitalisasi proses valuasi properti komersial di Indonesia.

Referensi

- Adetunji, A. B., Akande, O. N., Ajala, F. A., Oyewo, O., Akande, Y. F., & Oluwadara, G. (2021). House Price Prediction using *Random Forest Machine Learning* Technique. *Procedia Computer Science*, 199(February), 806–813. <https://doi.org/10.1016/j.procs.2022.01.100>
- Armstrong, J. S., & Collopy, F. (1992). Error measures for generalizing about forecasting methods: Empirical comparisons. *International Journal of Forecasting*, 8(1), 69–80. [https://doi.org/10.1016/0169-2070\(92\)90008-W](https://doi.org/10.1016/0169-2070(92)90008-W)
- Breiman, L. (2001). *Random Forests*. *Springer Nature*, 5–32. https://doi.org/10.1007/978-3-030-62008-0_35
- Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? -Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), 1247–1250. <https://doi.org/10.5194/gmd-7-1247-2014>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 13-17-Aug, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Cortes, C., Vapnik, V., & Saitta, L. (1995). *Support-Vector Networks*. 297, 273–297.
- Geltner, D., & Neufville, R. de. (2017). Real Estate Price Dynamics and the Value of Flexibility. *SSRN*, 1–51.
- Ho, W. K. O., Tang, B. S., & Wong, S. W. (2021). Predicting property prices with *machine learning* algorithms. *Journal of Property Research*, 38(1), 48–70. <https://doi.org/10.1080/09599916.2020.1832558>
- Ja'afar, N. S., Mohamad, J., & Ismail, S. (2021). *Machine learning* for property price prediction and price valuation: A systematic literature review. *Planning Malaysia*, 19(3), 411–422. <https://doi.org/10.21837/PM.V19I17.1018>
- James, G. (2013). *An Introduction to Statistical Learning with Applications in Python*. Springer. <https://www.statlearning.com/>
- Kasiram, M. (2010). *Metodologi Penelitian: Kualitatif - Kuantitatif*. UIN Maliki Press. <https://repository.uin-malang.ac.id/1621/>
- Kohavi, R., & Elu, S. (1993). A study of cross-validation and bootstrap for accuracy estimation and model selection. *Proceedings of*

- the 14th
13. *International Joint Conference on Artificial Intelligence*, 2, 1137–1143.
 14. Ma, Y., Zhang, Z., Ihler, A., & Pan, B. (2018). Estimating warehouse rental price using *machine learning* techniques. *International Journal of Computers, Communications and Control*, 13(2), 235–250. <https://doi.org/10.15837/ijccc.2018.2.3034>
 15. Mohd, T., Masrom, S., & Johari, N. (2019). *Machine learning* housing price prediction in petaling jaya, Selangor, Malaysia. *International Journal of Recent Technology and Engineering*, 8(2 Special Issue 11), 542–546. <https://doi.org/10.35940/ijrte.B1084.0982S1119>
 16. Olanrewaju, A. L., Xin, Y. L., Seong, Y. T., Jia, E. L., & Adnan, H. (2018). Factors Affecting Housing Prices in Malaysia: Analysis of the Supply Side. *Planning Malaysia*, 16(2), 225–235.
 17. Pagourtzi, E., Assimakopoulos, V., Hatzichristos, T., & French, N. (2003). Real estate appraisal: A review of valuation methods. *Journal of Property Investment & Finance*, 21(4), 383–401. <https://doi.org/10.1108/14635780310483656>
 18. Prigita, M., & Lantara, I. W. N. (2017). *ANALISIS FAKTOR YANG MEMENGARUHI NILAI SEWA RUKO DI PERUMAHAN SUMMARECON KELAPA GADING* [Universitas Gadjah Mada]. <https://etd.repository.ugm.ac.id/penelitian/detail/109636>
 19. Rahmawati, W. H., & Soeratno. (2012). *PENGARUH LOKASI DAN KARAKTERISTIK FISIK PROPERTI RUKO TERHADAP HARGA SEWA DI KECAMATAN DEPOK SLEMAN YOGYAKARTA* [Universitas Gadjah Mada]. <https://etd.repository.ugm.ac.id/penelitian/detail/56029>
 20. Shokoohyar, S., Sobhani, A., & Sobhani, A. (2020). Determinants of rental strategy: short-term vs long-term rental strategy. *International Journal of Contemporary Hospitality Management*, 13(12), 3873–3894. <https://doi.org/10.1108/IJCHM-03-2020-0185>
 21. Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79–82. <https://doi.org/10.3354/cr030079>